



Accuracy assessment of the One-Class SVM technique in identifying abnormalities in the vibration monitoring data of a gas turbine

Al-Tekreeti Watban Khalid Fahmi¹, Kazem Reza Kashyzadeh^{2*}, Siamak Ghorbani³

1- PhD student, Department of Mechanical Engineering Technologies, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya Street, Moscow 117198, Russian Federation.

2- Professor, Department of Transport, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya Street, Moscow 117198, Russian Federation.

3- Associate professor, Department of Mechanical Engineering Technologies, Academy of Engineering, RUDN University, 6 Miklukho-Maklaya Street, Moscow 117198, Russian Federation.

* P.O.B. 117198 Moscow, Russia, reza-kashi-zade-ka@rudn.ru

Article Information

Original Research Paper

Received 21 March 2024

Accepted 2 July 2024

Available Online 09

January 2026

Keywords

Power plant

Gas turbine

Fault detection

Vibration monitoring

Anomaly prediction

ABSTRACT

The existence of a strong and regular maintenance program in large industries such as power plants plays a vital role in preventing significant and irreparable damages to the system. In this article, the authors tried to evaluate the accuracy of one of the well-known methods, i.e., One-Class Support Vector Machine (SVM) technique, in the field of identifying anomalies related to the vibration data monitored in the power plant. For this purpose, a case study was conducted on the gas turbine of Kirkuk power plant located in Iraq. In this way, vibration monitoring was done by employing CA 202 piezoelectric accelerometer. After the analysis, the results indicate that the accuracy of this technique in detecting turbine vibration as a sign of a problem in the system is equal to 12.64%. These results emphasize the need for further research and modification of the proposed method because using the existing version of this technique without any development is ineffective to deal with the critical challenges in such industries, and in addition to not helping to reduce costs, it also leads to distrust of the system in other fault diagnosis methods.

Please cite this article using:

برای ارجاع به این مقاله از عبارت ذیل استفاده نمایید:

Al-Tekreeti Watban Khalid Fahmi, Kazem Reza Kashyzadeh, Siamak Ghorbani, Accuracy assessment of the One-Class SVM technique in identifying abnormalities in the vibration monitoring data of a gas turbine, *Journal of Mechanical Engineering and Vibration*, Vol. 16, No. 3, pp. 1-7, 2025 (In Persian)



ارزیابی دقت تکنیک ماشین بردار پشتیبانی تک کلاسه در شناسایی ناهنجاری‌ها در داده‌های پایش ارتعاش یک توربین گازی

التکریتی واطبان خالد فهمی^۱، کاظم رضاکاشی‌زاده^{۲*}، سیامک قربانی^۳

۱- دانشجوی دکتری، دانشکده فناوری‌های مهندسی مکانیک، آکادمی مهندسی، دانشگاه دوستی ملل روسیه، مسکو، روسیه

۲- استاد، دانشکده حمل و نقل، آکادمی مهندسی، دانشگاه دوستی ملل روسیه، مسکو، روسیه

۳- دانشیار، دانشکده فناوری‌های مهندسی مکانیک، آکادمی مهندسی، دانشگاه دوستی ملل روسیه، مسکو، روسیه

* روسیه، مسکو، خیابان میکلوخا-ماکلایا ۶، کدپستی ۱۱۷۱۹۸ پست الکترونیکی reza-kashi-zade-ka@rudn.ru

اطلاعات مقاله

چکیده

مقاله پژوهشی کامل

دریافت: ۲ فروردین ۱۴۰۳

پذیرش: ۱۲ تیر ۱۴۰۳

ارائه در سایت: ۱۹ دی ۱۴۰۴

کلیدواژگان

نیروگاه برق

توربین گازی

شناسایی عیوب

مانیتورینگ ارتعاش

پیش بینی ناهنجاری

وجود یک برنامه تعمیر و نگهداری مستحکم و منظم در صنایع بزرگ مانند نیروگاه‌های تولید برق و قدرت نقش بسزایی در جلوگیری از آسیب‌های قابل توجه و جبران ناپذیر به سیستم را ایفا می‌کند. در این مقاله، نویسندگان سعی دارند تا دقت یکی از روش‌های شناخته شده، یعنی تکنیک ماشین بردار پشتیبانی تک کلاسه (SVM)، را در حوزه شناسایی ناهنجاری‌های مربوط به داده‌های ارتعاشاتی مانیتور شده در نیروگاه برق را مورد ارزیابی قرار دهند. برای این منظور، مطالعه میدانی بر روی توربین گازی در نیروگاه برق کرکوک واقع در کشور عراق انجام شده است. بدین ترتیب که مانیتورینگ ارتعاشات توسط شتاب-سنج پیزوالکتریک CA 202 انجام شد. پس از تحلیل‌های انجام شده، نتایج حاکی از آن است که دقت این تکنیک در تشخیص لرزش توربین به عنوان نشانه‌ای از مشکل در سیستم برابر با ۱۲.۶۴ درصد است. این نتایج بر نیاز به تحقیق بیشتر و اصلاح روش پیشنهادی تاکید دارد چرا که استفاده از ورژن موجود این تکنیک بدون هیچ‌گونه توسعه، برای مقابله با چالش‌های حیاتی در چنین صناعی ناکارآمد است و علاوه بر عدم کمک به کاهش هزینه‌ها منجر به جلب اعتماد سیستم به دیگر روش‌های تشخیص عیب نیز می‌شود.

۱-مقدمه

گازی ناشی از ارتعاش در اثر نوسانات جریان بخار را نشان می‌دهد که در نیروگاه کرکوک عراق در سال ۲۰۲۱ اتفاق افتاده است. گزارش کامل این خرابی و تجزیه و تحلیل علل آن و اقدامات برای رفع آن در گزارش‌های فنی این نیروگاه بایگانی شده است که به دلیل محرمانگی اطلاعات از آوردن جزئیات آن خودداری شده است.

از اینرو، نظارت بر ارتعاشات در طول عملیات نیروگاه بسیار مهم است [۶]. با طراحی، نگهداری و نصب دقیق تجهیزات مورد نظر می‌توان از اثرات لرزش جلوگیری کرد. علاوه بر این، با تعیین منبع ارتعاش، می‌توان از طریق تعمیر و نگهداری پیشگیرانه در هزینه اضافی تعویض قطعات آسیب دیده صرفه‌جویی کرد [۷].

هر گونه ارتعاش غیرمنتظره‌ای که در قسمت‌های مختلف یک نیروگاه مشاهده می‌شود، می‌تواند نشانگر یک جزء رو به

تجزیه و تحلیل ارتعاش، به ویژه در ماشین‌های دوار، نقش مهمی در تشخیص زودهنگام عیب و ارزیابی شدت آسیب دارد [۱-۲]. در صنایع مختلف، روش‌های پیشنهادی زیادی برای تشخیص رایج‌ترین مشکلات مانند ناهماهنگی و عدم تعادل محور، عیوب یاتاقان‌ها و عیوب ساختاری و همچنین برای شناسایی محل دقیق آسیب رایج شده است. بطور کلی می‌توان چنین بیان داشت که با استفاده از تجزیه و تحلیل ارتعاش، می‌توان تا حدود ۸۰٪ از مشکلات اجزای چرخان، به ویژه خطاهای مربوط به روتور مانند ناهماهنگی و عدم تعادل را حذف یا کاهش داد [۳]. علاوه بر این، پیاده‌سازی یک رویکرد تعمیر و نگهداری پیشگیرانه موثر بسیار ارزان‌تر از هزینه متحمل از خرابی ماشین است [۴-۵]. شکل ۱ نمونه‌ای از آسیب وارد شده به توربین

پیش‌بینی تغییرات و حرکات لحظه‌ای غیر عادی در یک مجموعه داده معین، هدف اصلی پیش‌بینی در سری‌های زمانی است [۱۰]. برای استفاده از روش‌های پیش‌بینی، داده‌ها باید دارای بعد زمانی، ترتیب زمانی و میانگین متحرک در یک بازه زمانی از پیش تعیین‌شده باشند. ساختار شکنی داده‌ها، اطلاعات ضروری در مورد ویژگی‌های زمانی مانند روندها، فصلی بودن و باقیمانده‌ها را فراهم می‌سازد. برای پیش‌بینی سری‌های زمانی می‌توان از سه اصل فضای زمانی استفاده کرد: دوره کوتاه مدت (STP)، دوره میان مدت (MTP) و دوره بلند مدت (LTP) [۱۱-۱۲]. پیش‌بینی کوتاه مدت در یک دوره سه ماهه یا کمتر است، در حالی که پیش‌بینی بلند مدت در یک دوره دو ساله یا بیشتر است. این دوره‌ها را می‌توان بر اساس موضوع، مانند پیش‌بینی سری زمانی ترافیک، مجدداً طبقه‌بندی کرد [۱۳].

ماشین‌های دوار سیگنال‌های ارتعاشی ثابت تولید می‌کنند، اما در اکثر موارد تجزیه و تحلیل بر روی سیگنال‌های غیر ثابت با محتوای فرکانس در حال تغییر، به ویژه در سناریوهای خرابی ماشین‌آلات، با استفاده از تکنیک‌های تحلیل دامنه فرکانس-زمان تمرکز می‌کند [۱۴]. تکنیک‌های استاندارد در این رابطه شامل تبدیل فوریه کوتاه مدت، تجزیه و تحلیل موجک، تجزیه حالت تجربی و تجزیه میانگین محلی است [۱۵]. این روش‌ها سیگنال‌های یک بعدی حوزه زمانی را به توابع زمان-فرکانس دو بعدی تبدیل می‌کنند و تجزیه و تحلیل دقیق سیگنال‌ها را ارائه می‌دهند. در دهه گذشته، یادگیری ماشین (ML) و یادگیری عمیق (DL) در تشخیص عیب مبتنی بر داده بسیار مورد توجه قرار گرفته است. تکنیک‌های ML به‌طور گسترده به یادگیری تحت نظارت و بدون نظارت طبقه‌بندی می‌شوند. روش مورد نظر در این پژوهش، یعنی ماشین بردار پشتیبانی از نوع سیستم یادگیری نظارت شده است [۱۶] که برای طبقه‌بندی چندین خطا و پیش‌بینی خطاهای آینده بر اساس داده‌های قبلی ضروری هستند.


هدف اصلی این مقاله بررسی عملکرد الگوریتم SVM تک کلاسه در تشخیص ناهنجاری‌ها در داده‌های ارتعاش در یک نیروگاه برق به عنوان کارخانه تولیدی بزرگ و مهم از نظر اقتصادی است. به عبارت دیگر، میزان اثربخشی SVM تک کلاسه در شناسایی ناهنجاری‌ها بررسی می‌شود تا مشخص گردد که آیا این تکنیک قابل استفاده در برنامه‌های تعمیر و نگهداری پیشگیرانه مرتبط با این گونه صنایع هست یا خیر؟

زوال در نظر گرفته شود. بنابراین، با تجزیه و تحلیل سیگنال‌های ارتعاشی، احتمال خرابی بخش‌های مختلف یک نیروگاه را می‌توان به‌موقع شناسایی کرد و با اجرای یک سیستم نظارت بر ارتعاش و تشخیص خرابی خودکار، خطر آسیب‌های قابل توجهی که در حین کار سیستم رخ می‌دهد را کاهش یا حتی از بین برد [۸].




شکل ۱ تصویری از خرابی توربین در نیروگاه گازی کرکوک واقع در عراق

برای توصیف ساختار سیگنال ارتعاش به عنوان یک سری زمانی در یک سیستم مکانیکی، باید عناصر اصلی را در نظر گرفت که تغییرات در آن‌ها می‌تواند منجر به وقوع ارتعاش در سیستم شود. جابجایی‌ها، سرعت‌ها و شتاب‌ها اجزایی هستند که وقتی به عنوان تابعی از زمان تجزیه و تحلیل می‌شوند، می‌توانند به توصیف ویژگی‌های سیگنال ارتعاش در سناریوهای عملیاتی مختلف یک نیروگاه کمک کنند [۹]. شکل ۲ سیستم حفاظت از سرعت بیش از حد را نشان می‌دهد که برای نظارت بر سرعت توربین و وقوع ارتعاش در نیروگاه‌ها استفاده می‌شود.



شکل ۲ سیستم نصب شده در نیروگاه گازی کرکوک با هدف حفاظت از سرعت بیش از حد برای نظارت بر سرعت توربین‌ها و وقوع ارتعاش

هر عضو مجموعه یک سری زمانی حاوی ۴۰۰ نمونه است که بخشی از سیستم پایش بلادرنگ را تشکیل می‌دهد.



شکل ۴ ارتعاش نسبی محور توربین بر اساس جابجایی اندازه‌گیری شده توسط سنسورهای CA 202

۳-پیش‌پردازش داده‌ها

به منظور استفاده از تکنیک‌های یادگیری ماشین و قبل از مرحله آموزش، لازم است تا داده‌های ورودی پیش‌پردازش شوند و بطور کلی برای استفاده آماده گردند [۱۷-۱۹]. بدین منظور، روش‌های رایجی برای انجام پیش‌پردازش در سری‌های زمانی اعم از استانداردسازی و نرمال‌سازی داده‌ها وجود دارد. در این راستا، استانداردسازی داده‌ها با استفاده از معادله (۱) به گونه‌ای انجام می‌شود که میانگین داده‌ها و انحراف از معیار به ترتیب برابر با صفر و یک در نظر گرفته می‌شود. همچنین، معادله (۲) برای نرمال‌سازی داده‌ها استفاده می‌شود. بر اساس این عملگر، تبدیل داده‌ها به گونه‌ای است که محدوده از ۰ به ۱ یا ۱- به ۱ تنظیم می‌شود [۲۰].


$$x^o = \frac{x - x^*}{v} \quad (1)$$

$$x'' = \frac{x - (x)}{(x) - \min(x)} \quad (2)$$

که در آن x^o بیانگر سری زمانی استاندارد شده است، همچنین x و x^* به ترتیب سری‌های زمانی اصلی و میانگین تمام داده‌ها هستند. پارامتر v در معادله (۱) نشان‌دهنده انحراف استاندارد داده‌ها است. در معادله (۲)، x'' بیانگر داده‌های نرمال شده است. علاوه بر این، پاکسازی داده‌ها بر روی همه داده‌ها انجام شد تا مقادیر نادرست که در فرآیند جمع‌آوری داده رخ داده است حذف شوند. برای حفظ طول اولیه داده برای ورودی شبکه عصبی، مقدار صفر بجای مقادیر حذف شده در نظر گرفته شد تا به حفظ یکپارچگی ساختاری مجموعه داده کمک کند و

۲-گردآوری داده‌های ارتعاشی مرتبط با محور توربین گازی

اولین قدم در انتخاب یک تکنیک شبکه عصبی عمیق مناسب برای آموزش مدل، درک کامل ساختار داده‌های ورودی است [۱۷-۱۹]. به طور کلی، ساختار داده‌های ورودی را می‌توان به صورت ترتیبی یا غیر ترتیبی طبقه‌بندی کرد. زمانی که ترتیب اعضای یک مجموعه داده بسیار مهم باشد، داده‌ها را می‌توان به صورت متوالی در نظر گرفت. از طرفی، سری‌های زمانی شکلی تکراری از داده‌های متوالی است که عناصر هر مجموعه داده نشان‌دهنده رویدادی است که در زمان خاصی رخ داده است. برای این مطالعه، داده‌ها از نیروگاه گازی کرکوک جمع‌آوری شد که نشان‌دهنده سوابق سه سنسور شتاب‌سنج پیزوالکتریک CA 202 از ماه مارس سال ۲۰۲۰ تا پایان ماه اکتبر سال ۲۰۲۱ (به مدت ۲۲ ماه) است. اطلاعات جمع‌آوری شده توسط یک سیستم نظارت بر لرزش، "VIBRO-METER" اندازه‌گیری شد و ارتعاش نسبی محور را به عنوان جابجایی ارتعاش اندازه‌گیری کرد. وابسته به محل نصب سنسورها در توربین گازی، هر سری زمانی رفتار متفاوتی نسبت به سری‌های دیگر در طول زمان نشان می‌دهد. الگوهای سری زمانی که به طور غیرمنتظره تغییر می‌کنند، رفتار غیرعادی تلقی می‌شوند (به دلیل محدودیت‌های اعمال شده توسط شرکت نیروگاه گازی کرکوک و حفظ امنیت اطلاعات آن شرکت، از ارایه داده‌های کامل سنسورها در این مقاله خودداری شده است). شکل ۳ تصویری از سنسورهای نصب شده در نیروگاه کرکوک را نشان می‌دهد.



شکل ۳ شتاب سنج CA 202 نصب شده در نیروگاه کرکوک

علاوه بر این، نمونه‌ای از مجموعه داده‌هایی که برای این مقاله جمع‌آوری شده است، در شکل ۴ نشان داده شده است.

مدل با پارامتر $nu=0.05$ تنظیم شده است، که حساسیت مدل به ناهنجاری‌ها را کنترل می‌کند. مقدار کمتر nu باعث می‌شود که مدل نسبت به موارد پرت حساس‌تر شود [۲۲].

Algorithm 2 One-Class SVM Algorithm

```

1: Input: Data  $X$ ,  $nu$  parameter  $\nu$ 
2: Output: Anomaly scores  $scores$ 
3:
4: Procedure:
5: Normalize the data  $X$  using a suitable normalization technique
6: Split the normalized data into training and testing sets
7: Initialize the One-Class SVM model with parameter  $\nu$ 
8: Train the One-Class SVM model using the training data
9: Function PredictAnomalyScores( $X$ , model):
10: Predict anomaly scores for the data  $X$  using the trained model
11: return Anomaly scores  $scores$ 
12: Call the PredictAnomalyScores function with the testing data and trained model
13: return Anomaly scores  $scores$ 

```

۵- نتایج

دقت مدل با استفاده از معادله (۳) ارزیابی شد. در این معادله TP و TN به ترتیب بیان‌کننده تعداد منفی‌ها و مثبت‌هایی است که به درستی توسط الگوریتم تشخیص داده شده‌اند. به همین ترتیب، FN و FP به ترتیب بیان‌کننده تعداد منفی‌ها و مثبت‌هایی است که به اشتباه توسط الگوریتم تشخیص داده شده‌اند [۲۱].

$$Accuracy = \frac{TN+TP}{TN+TP+FN+FP} \times 100\% \quad (3)$$

نتایج نشان می‌دهد که تکنیک ماشین بردار پشتیبانی تک کلاسه در تشخیص ناهنجاری مربوط به محور توربین گازی دارای دقت نسبتاً پایینی است (۱۲.۶۴٪). این آمار بیان‌کننده این واقعیت است که بکارگیری این تکنیک ایده مناسبی نبوده و نیاز به اصلاح و توسعه دارد. برای درک بهتر از منبع خطا در این تکنیک، به جزییات تشخیص درست و یا نادرست حالت‌های مختلف (ماتریس سردرگمی) پرداخته شد. شکل ۵ نشان‌دهنده ماتریس سردرگمی مربوط به تحلیل داده‌ها بر اساس تکنیک SVM تک کلاسه است. نتایج نشان داد که این مدل تعداد ۴۷۰ مورد مثبت کاذب را ثبت کرده است که نشان‌دهنده نرخ طبقه‌بندی اشتباه بالا است، که به‌ویژه در تشخیص ناهنجاری که دقت تشخیص حیاتی است، مشکل‌ساز است.

اطمینان حاصل شود که اندازه ورودی برای شبکه عصبی ثابت باقی می‌ماند. در ادامه، به دلیل کمبود داده‌های غیرعادی در مجموعه داده مورد مطالعه، داده‌های غیرعادی به صورت دستی از داده‌های اصلی با انواع مختلف روش‌های ناهنجاری تولید شدند. بدین ترتیب که نمونه‌های غیرعادی از طریق چرخش متقارن و اضافه کردن نویز (نویز سفید با توزیع گوسی) گسترش یافت.


۴- تشخیص ناهنجاری

هدف این مقاله بررسی اجرای تکنیک SVM تک کلاسه در شناسایی ناهنجاری‌ها در داده‌های پایش ارتعاش یک توربین گازی است. این تکنیک برای تشخیص الگوهای پیچیده در داده‌های سری زمانی مفید است. ماشین‌های بردار پشتیبانی (SVM) در دهه گذشته در یادگیری ماشین محبوبیت زیادی پیدا کردند. SVM تک کلاسه یک شکل نیمه نظارت شده از تشخیص ناهنجاری است که فقط از داده‌های عادی برای آموزش جهت شناسایی ناهنجاری‌ها استفاده می‌کند. همچنین می‌توان از آن در راه‌اندازی تشخیص ناهنجاری بدون نظارت بدون هیچ‌گونه آموزش قبلی استفاده کرد. با این حال، SVM‌های تک کلاسه در برابر داده‌های پرت آسیب‌پذیر هستند. SVM‌ها به‌طور گسترده در یادگیری ماشین برای کاربردهای مختلف مانند شناسایی ارقام دست‌نویس، اشیاء، بلندگوها و متن استفاده می‌شوند.

ماشین بردار پشتیبانی تک کلاسه به عنوان یک مدل یادگیری ماشین تخصصی برای تشخیص ناهنجاری طراحی شده است. کارکرد آن بر اساس اصل شناسایی نقاط داده‌ای است که به‌طور قابل توجهی از هنجار منحرف می‌شوند. بر خلاف SVM‌های سنتی که وظایف طبقه‌بندی شامل چندین کلاس را مدیریت می‌کنند، SVM تک کلاسه فقط بر روی یک کلاس واحد از داده‌ها تمرکز دارد. این رویکرد به‌ویژه در سناریوهایی مفید است که بسیاری از داده‌ها رفتار «عادی» را نشان می‌دهند و ناهنجاری‌ها نادر یا تعریف‌نشده هستند. این مدل با استفاده از یک تابع مرکزی، داده‌های ورودی را در یک فضای ویژگی با ابعاد بالا نگاشت می‌کند، و تلاش می‌کند تا بسیاری از نقاط داده را در داخل محدوده بسته قرار دهد و در عین حال موارد پرت را حذف کند. الگوریتم استفاده شده در این پژوهش بصورت زیر است [۲۱].

۸-مراجع

- [1] A.T.W.K. Fahmi, K.R. Kashyzadeh, S. Ghorbani, A comprehensive review on mechanical failures cause vibration in the gas turbine of combined cycle power plants, *Engineering Failure Analysis*, Vo. 134, 2022.
- [2] A.T.W.K. Fahmi, K.R. Kashyzadeh, S. Ghorbani, Industrial vibration detection techniques for enhanced monitoring and maintenance of combined cycle power plants, in *International Conference on Engineering Systems*, Moscow, Russian Federation, 5-7 April 2023.
- [3] C. Scheffer, P. Girdhar, *Practical machinery vibration analysis and predictive maintenance*, 1st Edition, Newnes: Elsevier, 2004.
- [4] S. Karmakar, S. Chattopadhyay, M. Mitra, S. Sengupta, Induction motor fault diagnosis: General discussion and research scope, in *Karmakar S, Chattopadhyay S, Mitra M and Sengupta S. (eds) Induction Motor Fault Diagnosis*, Singapore: Springer, 2016.
- [5] S. Zare, Fault detection and diagnosis of electric drives using intelligent machine learning approaches, PhD Thesis, University of Windsor, Canada, 2018.
- [6] D. Goyal, BS. Pabla, The vibration monitoring methods and signal processing techniques for structural health monitoring: a review, *Arch Comput Methods Eng.*, Vol. 23, No. 4, pp. 585-594, 2016.
- [7] S.J. Lacey, The Role of Vibration Monitoring in Predictive Maintenance Part 1-Principles and Practice, *Maintenance & Asset Management. Maintenance & Engineering Magazine*, Vol. 24, No. 1, pp. 42-51, 2011.
- [8] RK. Mobley, 50 - Predictive Maintenance, *Mobley RK (eds) Plant Engineer's Handbook*, 1st Edition, Butterworth: Elsevier, 2001.
- [9] E. Losi, M. Venturini, L. Manservigi, GF. Ceschini, G. Bechini, Anomaly detection in gas turbine time series using bayesian hierarchical models, *J Eng Gas Turbines Power*, Vol. 141, No. 11, 2019.
- [10] GP. Zhang, Time series forecasting using a hybrid ARIMA and neural network model, *Neurocomputing*, Vol. 50, pp. 159-175, 2003.
- [11] K. Koc, Ö. Ekmekcioğlu, AP. Gurgun, Accident prediction in construction using hybrid wavelet-machine learning, *Automation in Construction*, Vol. 133, 2022.
- [12] D. Solyali, A comparative analysis of machine learning approaches for short-/long-term electricity load forecasting in Cyprus, *Sustainability*, Vol. 12, No. 9, 2020.
- [13] G. Mahalakshmi, S. Sridevi, S. Rajaram, A survey on forecasting of time series data. in *International Conference on Computing Technologies and Intelligent*



شکل ۵ ماتریس سردرگمی برای مدل تشخیص ناهنجاری ماشین بردار پشتیبان تک کلاسه بکارگرفته شده بر روی داده‌های ارتعاش محور توربین گازی در نیروگاه کرکوک واقع در عراق

۶-جمع‌بندی

این مقاله میزان کارایی یک رویکرد مبتنی بر آستانه را برای شناسایی عیوب در توربین‌های گازی با استفاده از یک مدل پیش‌بینی ترسیم می‌کند. داده‌های مورد استفاده در این مطالعه از نیروگاه توربین گازی کرکوک با استفاده از شتاب‌سنج پیزوالکتریک CA 202 جمع‌آوری شده است. دقت مدل بردار پشتیبان تک کلاسه مورد ارزیابی قرار گرفت که دارای عملکرد خوبی نبود (دقت تشخیص ناهنجاری در حدود ۱۲٪). در نهایت، نیاز به تحلیل و ارزیابی بیشتر در این الگوریتم به منظور تعیین اینکه آیا این مدل قابل بهبود هست یا باید مدل‌های جایگزین در نظر گرفته شوند، است. در نهایت باید اذعان داشت که هنگام انتخاب یک روش تشخیص، باید بر دقت و قابلیت اطمینان مدل برای افزایش کارایی عملیاتی و قابلیت اطمینان تشخیص خطای توربین گاز تأکید شود. این امر منجر به بهبود قابل توجهی در کارایی سیستم‌های تشخیص عیب برای توربین‌های گازی می‌شود و در پی آن، منجر به افزایش کارایی و قابلیت اطمینان عملیاتی و در نهایت کاهش هزینه‌های تولید می‌گردد.

۷-تقدیر و تشکر

این مقاله مستخرج شده از رساله دکتری دانشجوی مهندسی مکانیک در دانشگاه دوستی ملل روسیه تحت نظارت پروفسور کاظم رضاکاشی‌زاده به عنوان استاد راهنما و جناب آقای دکتر سیامک قربانی به عنوان استاد مشاور است. همچنین، این رساله بصورت یک کار صنعتی مشترک بین دانشگاه و نیروگاه بوده است. لذا از تمام عزیزانی که در حوزه‌های مختلف جهت به ثمر رساندن این پژوهش یاری رساندند، کمال تشکر و قدردانی را دارد.

Data Engineering (ICCTIDE'16), Kovilpatti, India, 7-9 January 2016.

- [14] M. Huang, Z. Liu, Research on mechanical fault prediction method based on multi-feature fusion of vibration sensing data, *Sensors*, Vol. 20, No. 1, 2019.
- [15] S. Gawde, S. Patil, S. Kumar, P. Kamat, K. Kotecha, A. Abraham, Multi-fault diagnosis of Industrial Rotating Machines using Data-driven approach: A review of two decades of research, *Engineering Applications of Artificial Intelligence*, Vol. 123, 2023.
- [16] Y.E. Lee, B.K. Kim, J.H. Bae, K.C. Kim, Misalignment detection of a rotating machine shaft using a support vector machine learning algorithm, *International Journal of Precision Engineering and Manufacturing*, Vol. 22, pp. 409-416, 2021.
- [17] E. Maleki, O. Unal, S.S. Sahebari, K.R. Kashyzadeh, A Novel Approach for Analyzing the Effects of Almen Intensity on the Residual Stress and Hardness of Shot-Peened (TiB+TiC)/Ti-6Al-4V Composite: Deep Learning, *Materials*, Vol. 16, 2023..
- [18] K.R. Kashyzadeh, S. Ghorbani, New neural network-based algorithm for predicting fatigue life of aluminum alloys in terms of machining parameters, *Engineering Failure Analysis*, Vol. 146, 2023..
- [19] E. Maleki, O. Unal, S.M.S. Sahebari, K.R. Kashyzadeh, N. Amiri, Enhancing Friction Stir Welding in Fishing Boat Construction through Deep Learning-Based Optimization, *Sustainable Marine Structures*, Vol. 5, No. 2, pp. 1-14, 2023.
- [20] Q. Wang, H. Qi, F. Liu, Time series prediction of E-nose sensor drift based on deep recurrent neural network, in *Chinese Control Conference (CCC)*, Guangzhou, China, 27-30 July 2019.
- [21] A.T.W.K. Fahmi, K.R. Kashyzadeh, S. Ghorbani, Fault Detection in the Gas Turbine of the Kirkuk Power Plant: An Anomaly Detection Approach Using DLSTM-Autoencoder, *Engineering Failure Analysis*, Vol. 160, 2024.
- [22] M. Amer, M. Goldstein, S. Abdennadher, Enhancing one-class support vector machines for unsupervised anomaly detection, in *Proceedings of the ACM SIGKDD workshop on outlier detection and description*, 2013.